

SUI MAGGIORANTI DELLA DISTRIBUZIONE ASINTOTICA DI UN INDICE DI CONCENTRAZIONE FRA LE CLASSI DI GINI*

Michele ZENGA - Antonio BRUNAZZO**

0. Sommario

Nelle indagini socio-economiche, spesso si hanno problemi che riguardano la difforme distribuzione di una quantità trasferibile fra le k classi in cui può essere divisa una popolazione. Una misura della concentrazione fra le classi è data dal noto indice di concentrazione di Gini:

$$A = \frac{D_r}{2\bar{X}}$$

in cui D_r indica la differenza media assoluta con ripetizione fra le medie delle classi e \bar{X} indica, come al solito, la media aritmetica generale della quantità trasferibile. Con semplici passaggi è facile esprimere l'indice di concentrazione fra le classi anche nel seguente modo:

$$A = \frac{1}{2} \sum_{i=1}^k \sum_{j=1}^k |p_i q_j - p_j q_i|$$

in cui:

- i) p_i indica la frequenza relativa delle unità appartenenti alla classe $i^{m.a}$;
- ii) q_i indica la quota del carattere trasferibile spettante alla classe $i^{m.a}$.

Nell'ipotesi in cui sono noti i valori di q_i della popolazione e si disponga di un campione bernoulliano che permetta di stimare le frequenze relative p_i

* Lavoro presentato, in forma ristretta, alla XXXI riunione scientifica della Società Italiana di Statistica, Torino 5-7 aprile 1982. I capitoli 0,1,2,3 sono dovuti a M. Zenga mentre i capitoli 4,5,6 e 7 sono dovuti a A. Brunazzo.

** Facoltà di Economia e Commercio, Libera Università degli Studi di Trento

della popolazione attraverso le frequenze \hat{p}_i del campione, è possibile misurare la concentrazione campionaria fra le classi con la statistica:

$$G = \frac{1}{2} \sum_{i=1}^k \sum_{j=1}^k | \hat{p}_i q_j - \hat{p}_j q_i |$$

La distribuzione asintotica di G è stata ricavata da Colombi [1] nel caso $\Delta = 0$ e $k = 3$ e da Brunazzo [2] nel caso $\Delta = 0$, $k = 4$ e $q_1 = q_2 = q_3 = q_4 = \frac{1}{4}$.

In questo lavoro, sempre per l'ipotesi $\Delta = 0$, si ricavano con due diverse procedure, valori maggioranti dei quantili di G . La prima procedura utilizza la classica disuguaglianza di Bonferroni, l'altra utilizza la distribuzione della v.c. Chi-quadrato centrale.

Le due procedure, in qualche modo, si compensano nel senso che, per valori piccoli di k , i maggioranti che si ricavano con la disuguaglianza di Bonferroni sono minori degli altri ed all'aumentare di k le posizioni si invertono.

Il grado di approssimazione fra i maggioranti qui proposti ed i valori esatti dei quantili trovati da Colombi e da Brunazzo per il caso $k = 3$ e $k = 4$ è del tutto soddisfacente e giustifica l'impiego dei maggioranti in problemi di inferenza statistica.

1. Introduzione e simbologia

Si indichi con X l'intensità di un carattere trasferibile di cui si vuole misurare la concentrazione fra le k classi in cui è divisa la popolazione. Sia N_i il numero delle unità appartenenti alla classe $i^{m.a}$ ($i = 1, 2, \dots, k$) e sia X_{ij} l'intensità della generica $j^{m.a}$ unità della $i^{m.a}$ classe ($j = 1, 2, \dots, N_i$).

E' possibile, così calcolare le seguenti grandezze statistiche:

$$\begin{aligned} \text{i) } p_i &= \frac{N_i}{\sum_{i=1}^k N_i} \\ &= \frac{N_i}{N}, \quad \text{frequenza relativa delle unità appartenenti alla classe } i^{m.a}. \end{aligned}$$

$$\text{ii) } \bar{X}_i = \frac{\sum_{j=1}^{N_i} X_{ij}}{N_i}, \text{ media aritmetica del carattere nella classe } i^{\text{m.a}};$$

$$\text{iii) } \bar{X} = \frac{\sum_{i=1}^k N_i \bar{X}_i}{\sum_{i=1}^k N_i}, \text{ media aritmetica generale};$$

$$\text{iv) } Q_i = N_i \bar{X}_i, \text{ quantità del carattere appartenente alla classe } i^{\text{m.a}};$$

$$\begin{aligned} \text{v) } q_i &= \frac{Q_i}{\sum_{i=1}^k Q_i} \\ &= \frac{N_i \cdot \bar{X}_i}{N \bar{X}} \text{ quota del carattere appartenente alla classe } i^{\text{m.a}}. \end{aligned}$$

Per misurare la concentrazione fra le classi si può usare l'indice di concentrazione di Gini:

$$\Delta = \frac{D_r}{2\bar{X}}$$

in cui D_r indica la differenza media assoluta con ripetizione fra le medie \bar{X}_i delle classi. La concentrazione fra le classi, si può, esplicitando l'espressione di D_r , riscrivere come segue:

$$\Delta = \frac{1}{2\bar{X}} \sum_{i=1}^k \sum_{j=1}^k \left| \bar{X}_j - \bar{X}_i \right| = \frac{1}{2} \sum_{i=1}^k \sum_{j=1}^k \left| \frac{\bar{X}_j}{\bar{X}} - \frac{\bar{X}_i}{\bar{X}} \right| p_i p_j .$$

Tenuto presente che $\frac{\bar{X}_i}{\bar{X}} = \frac{q_i}{p_i}$, l'espressione precedente diventa:

$$\Delta = \frac{1}{2} \sum_{i=1}^k \sum_{j=1}^k \left| p_i q_j - p_j q_i \right| . \quad (1.1)$$

Nell'ipotesi di equiripartizione si ha:

$$\Delta = 0 \leftrightarrow p_i = q_i \quad (i = 1, 2, \dots, k).$$

Si estragga, con riposizione, dalla popolazione un campione casuale di ampiezza n e si indichi n_i il numero delle unità estratte appartenenti alla classe i^{ma} (ovviamente: $n_i > 0; i = 1, 2, \dots, k; \sum n_i = n$). Le frequenze (n_1, n_2, \dots, n_k) costituiscono la determinazione campionaria di una distribuzione multinomiale $(n; p_1, p_2, \dots, p_k)$. Nell'ipotesi in cui siano noti i valori q_i della popolazione, dai dati campionari è possibile calcolare l'indice di Gini che assumerà la forma:

$$G = \frac{1}{2} \sum_{i=1}^k \sum_{j=1}^k \left| \frac{n_i}{n} q_j - \frac{n_j}{n} q_i \right| \quad (1.2)$$

Nei paragrafi che seguono si indagherà sulla distribuzione campionaria della (1.2) nell'ipotesi che $\Delta = 0$.

2. Impiego della disuguaglianza di Bonferroni, caso $k = 3$

In questo paragrafo verrà esaminato, in dettaglio, il procedimento che ha permesso di ricavare i maggioranti con l'uso della disuguaglianza di Bonferroni. Si è preferito esaminare a parte il caso $k = 3$ in quanto la trattazione per un k generico risulta abbastanza complessa, come si noterà nel paragrafo 4 e seguenti. Con semplici passaggi è possibile descrivere la (1.2) come segue:

$$G = \frac{1}{n} \left\{ q_1 q_2 \left| \frac{n_1}{q_1} - \frac{n_2}{q_2} \right| + q_1 q_3 \left| \frac{n_1}{q_1} - \frac{n_3}{q_3} \right| + q_2 q_3 \left| \frac{n_2}{q_2} - \frac{n_3}{q_3} \right| \right\}. \quad (2.1)$$

Si considerino ora le seguenti sei regioni R_i , ($i = 1, 2, \dots, 3!$) dello spazio R^2 :

$$R_1 = \left\{ (n_1, n_2, n_3) : \frac{n_3}{q_3} \leq \frac{n_2}{q_2} \leq \frac{n_1}{q_1} \right\}$$

$$R_2 = \left\{ (n_1, n_2, n_3) : \frac{n_1}{q_1} \leq \frac{n_2}{q_2} \leq \frac{n_3}{q_3} \right\}$$

$$R_3 = \left\{ (n_1, n_2, n_3) : \frac{n_3}{q_3} \leq \frac{n_1}{q_1} \leq \frac{n_2}{q_2} \right\}$$

$$R_4 = \left\{ (n_1, n_2, n_3) : \frac{n_2}{q_2} \leq \frac{n_1}{q_1} \leq \frac{n_3}{q_3} \right\}$$

$$R_5 = \left\{ (n_1, n_2, n_3) : \frac{n_2}{q_2} \leq \frac{n_3}{q_3} \leq \frac{n_1}{q_1} \right\}$$

$$R_6 = \left\{ (n_1, n_2, n_3) : \frac{n_1}{q_1} \leq \frac{n_3}{q_3} \leq \frac{n_2}{q_2} \right\}$$

Si indichi con G_i l'espressione con cui si può scrivere la (2.1), senza ricorrere ai valori assoluti, nell'ipotesi $(n_1, n_2, n_3) \in R_i$.

In particolare si ha:

$$G_1 = \frac{1}{n} \left\{ q_1 q_2 \left(\frac{n_1}{q_1} - \frac{n_2}{q_2} \right) + q_1 q_3 \left(\frac{n_1}{q_1} - \frac{n_3}{q_3} \right) + q_2 q_3 \left(\frac{n_2}{q_2} - \frac{n_3}{q_3} \right) \right\};$$

$$G_2 = -G_1;$$

$$G_3 = \frac{1}{n} \left\{ -q_1 q_2 \left(\frac{n_1}{q_1} - \frac{n_2}{q_2} \right) + q_1 q_3 \left(\frac{n_1}{q_1} - \frac{n_3}{q_3} \right) + q_2 q_3 \left(\frac{n_2}{q_2} - \frac{n_3}{q_3} \right) \right\};$$

$$G_4 = -G_3;$$

$$G_5 = \frac{1}{n} \left\{ q_1 q_2 \left(\frac{n_1}{q_1} - \frac{n_2}{q_2} \right) + q_1 q_3 \left(\frac{n_1}{q_1} - \frac{n_3}{q_3} \right) - q_2 q_3 \left(\frac{n_2}{q_2} - \frac{n_3}{q_3} \right) \right\};$$

$$G_6 = -G_5.$$

Riordinando i termini delle espressioni precedenti e ricordando che $n_3 = n - n_1 - n_2$, si ha ancora:

$$G_1 = \frac{1}{n} \left\{ n_1 (1 + q_2) + n_2 (1 - q_1) - n (1 - q_3) \right\}; \quad (2.2)$$

$$G_3 = \frac{1}{n} \left\{ n_1 (1 - q_2) + n_2 (1 + q_1) - n (1 - q_3) \right\}; \quad (2.3)$$

$$G_5 = \frac{1}{n} \left\{ n_1 (1 - q_2) - n_2 (1 - q_1) - n (q_1 - q_2) \right\}. \quad (2.4)$$

Ovviamente è possibile considerare la G_i anche fuori dalla regione R_i , però il suo valore, in questo caso, non coincide con quello di G .

Si consideri ora il luogo dei punti dello spazio campionario R^2 in cui $G_1 = -g$, ($g > 0$): trattasi dei punti caratterizzati dalla retta di equazione:

$$n_1 (1 + q_2) + n_2 (1 - q_1) - n (1 - q_3) = ng.$$

